

AI による配電設備の点検・保守支援

AI-based Decision Support for Inspection and Maintenance of Power Distribution Equipment

高野浩貴*

1. はじめに

配電ネットワークは、配電線、コンクリート電柱、柱上変圧器、開閉器などの様々な設備で構成される。配電ネットワーク管理者（DNO：Distribution Network Operators）は、配電ネットワークにおける電力供給の信頼性を確保するため、定期的に配電設備を点検する。また、異常を発見した際には、その内容や程度に応じた対策を施す¹⁾。点検結果（項目別のスコアなど）や保守内容（経過観察や修繕など）は記録として蓄積され、同種の設備の保守要否を判断する際などに参考として用いられる。

配電設備は、高度経済成長期の電力需要の増加に伴って新設・増設されたものが多く、いずれの設備でも経年分布には大きな偏りが見られる²⁾。加えて、人口減少や省エネ機器の普及に伴う設備の更新機会の減少、電気保安人材の高齢化などの影響もあり、従来通りの経年に応じた設備更新では対処しきれなくなることが予想される。この対処方策として、AI や IoT 技術を活用した新しい電気保安が注目されている^{3, 4)}。その一つに、前述のように蓄積された記録を、配電ネットワークの運用・計画に積極的に利用することが考えられる。蓄積された記録には、DNO の知識や経験が反映されており、それらを抽出して活用できれば、配電ネットワークの運用・計画の効率化に繋がる可能性は高い^{5, 6)}。

著者らは、決定木学習によって点検・保守記録を分析し、新たな点検結果に対して保守要否を自動判定するモデルを構築する取り組みを行ってきた^{7, 8)}。また、決定木学習の持つ、結果の可読性が高いという特長に着目し、保守要否の判断に強く影響したであろう点検項目を特定することも試みてきた^{7, 8)}。本稿は、これらの取り組みを元に執筆したものである。

2. 判定モデルの作成条件

今回使用するのは、2013～2017 年度のコンクリート電柱、柱上変圧器の通常点検の記録と保守記録である。表 1 にコンクリート電柱の内訳、表 2 に柱上変圧器の内訳を示す。

DNO は、著者らの保有する記録のみを用いて配電設備を管理しているわけではない。そのため、著者らが保有する記録のみでは判別できない設備など、そのままでは使用できないものも含まれている。そこで、これらを除外した、コンクリート電柱 1201648、柱上変圧器 330334 台を検討対象とした。なお、「何かしらの異常を持つ設備」とは、点検ス

表 1 コンクリート電柱の内訳

コンクリート電柱の総数	1382067 本
対象とするコンクリート電柱の総数	1201648 本
何かしらの異常を持つと判断された コンクリート電柱の総数	169671 本
内、建て替えと判断された コンクリート電柱の総数	1896 本

表 2 柱上変圧器の内訳

柱上変圧器の総数	1056191 台
対象とする柱上変圧器の総数	330334 台
何かしらの異常を持つと判断された 柱上変圧器の総数	52842 台
内、取り替えと判断された 柱上変圧器の総数	1755 台

* 岐阜大学 工学部 電気電子・情報工学科

コアに1以上の値を含む設備を指す(2.1節参照)。実務上支障をきたす設備とは限らない点に留意されたい。

2.1 点検・保修記録の概要

点検記録には、設備のID、巡視日、巡視者名、点検項目、点検スコアなどが記載されている。点検スコアは、点検項目別に非負の整数で定義されており、異常が無ければゼロ、異常が深刻なほど大きな値を取る。設備の状態とは直接関係しない項目を含むこともあるが、これらは除外することとした。表3、4は、使用したコンクリート電柱、柱上変圧器それぞれの点検項目の概要である。なお、今回は、各設備の設置エリアの情報も使用するため、エリア番号にも記号を割り当てている(コンクリート電柱ではCP0、柱上変圧器ではPT0)。

保修記録には、保修が必要と判断された設備のID、判断した日付、保修内容、保修完了予定日などが記載されている。保修内容としては、経過観察、各種修繕の他、コンクリート電柱の場合は建て替え、

表3 コンクリート電柱の点検項目

変数記号	点検項目
CP0	エリア番号
CP1	地際部に関する項目
CP2	傾斜・湾曲に関する項目
CP3	ひび割れの様相に関する項目
CP4	
CP5	
CP6	剥離に関する項目
CP7	
CP8	
CP9	

表4 柱上変圧器の点検項目

変数記号	点検項目
PT0	エリア番号
PT1	各部位(外箱側面、外箱底面など)のさび・腐食に関する項目
PT2	
PT3	
PT4	
PT5	
PT6	
PT7	

柱上変圧器の場合は取り替えなどが記載されている。簡単のため、建て替え・取り替えの可否のみを判定するものとし、建て替え・取り替えと記載された設備を異常サンプルと定義した。一方、建て替え・取り替え以外の項目が記載されたものは、異常は確認されたものの運用可能と判断された設備と見なし、学習上の正常サンプルとして扱うこととした。

2.2 使用するデータ

著者らの保有する点検記録と保修記録は個別に管理されているが、設備IDによって双方を紐づけることができる。そこで、設備IDを用いて両記録を統合し、設備ID、エリア番号、点検結果(点検項目とそのスコア)、建て替え・取り替えの可否(要:1、否:0)で構成されるデータ群を準備した。表1に示した通り、コンクリート電柱の場合、正常サンプルは167775本、異常サンプルは1896本である。一方、表2に示した通り、柱上変圧器の場合、正常サンプルが51087台、異常サンプルが1755台となる。これらを用いて、保修要否(建て替え・取り替え要否)の判定モデルを構築する。

3. 判定モデルの構築手法

AIとは、人間と同様の知的な作業をする機械を、工学的に実現する技術と定義されることがある⁹⁾。機械学習はこのAIの一種とされ、データが潜在的に持つ特徴や構造を発見したり、その関係を用いて新たなデータを予測したりする際に有効とされる。教師データの有無によって、教師あり学習と教師なし学習とに大別されることが多い。ここでは、点検項目(エリア番号も含む)を説明変数、建て替え・取り替えの可否を目的変数に対応させ、教師あり学習の一つである決定木学習を用いるものとした。

3.1 決定木学習の概要

決定木学習は、説明変数に対する条件分岐を繰り返すことでデータを分類する。この分岐過程を階層化して樹木図で表現したモデルを“決定木”と呼ぶ。決定木では、分類を“葉”，その分類に至るまでに必要とされる条件を“枝”と表現する。決定木の葉や枝の持つ情報を整理することで、どの説明変数が条件分岐に影響を与えたのかを視覚的に提供できる点に特長を持つ^{10, 11)}。著者らの取り組みでは、建て替え・取り替え要否の判断に影響を与えた説明変数を明らかにすることも目的とするため、この特長を重視して決定木学習を採用することとしている。

3.2 決定木学習の適用

決定木には分類木と回帰木の二種類がある。データの分類や判定を目的とする場合は分類木、数値などの推定を目的とする場合は回帰木を用いる。今回は、目的変数を建て替え・取り替えの要(1)、不要(0)の2値としたため、分類木を用いる。決定木を構築する代表的なアルゴリズムには、Classification and Regression Tree (CART), Iterative Dichotomiser 3 (ID3), Successor of ID3 (C4.5)が挙げられる¹²⁻¹⁴⁾。ここではCARTアルゴリズムを取り上げる。

CARTアルゴリズムは、木の“成長”と枝の“剪定”という過程を経て決定木を構築する。まず、予め定めた収束判定基準を満たすまで、対象データの分岐を繰り返して最大木を構築する。これが成長である。分岐の条件には、(1)式のジニ係数を用いた。 x はノード番号(1, 2, ..., X), y はクラス番号(1, 2, ..., Y), $p(y|x)$ はクラス y に属するサンプルデータがノード x に占める割合である。分岐後のノードを構成する学習データのジニ係数の合計が最大となるように分岐条件を定めている。

$$G_x = 1 - \sum_{y=1}^Y p(y|x)^2 \quad (1)$$

最大木は、学習データに過剰適合したものとなっている可能性がある。そのため、成長させた木から不要な枝を除外する。これが剪定である。除外する枝の選定基準には、(2)式のコスト複雑度を用いた¹⁵⁾。 L は終端ノード(葉)の集合、 D_x はノード x に含まれる学習データの数、 D はモデル作成に使用した学習データの総数、 α は制御パラメータである。これにより決定木が得られる。

$$R_\alpha = \sum_{x \in L} \left(G_x * \frac{D_x}{D} \right) + \alpha |L| \quad (2)$$

前述の通り、得られた決定木から、条件分岐に影響を与えた説明変数がある程度見出すことはできる。しかしながら、そのみで説明変数の持つ影響の度合いを測ることは難しい。そこで、本論文では、(3)式の変数重要度を用いて¹⁵⁾、説明変数の影響を数値として評価することとした。 M は終端ノードを除くノードの集合、 $\Delta G_x(i_y)$ は入力項目 i_y でノード x を分割した際のジニ係数の減少量である。

$$V = \sum_{x \in M} \Delta G_x(i_y) \quad (3)$$

図1は、成長、剪定の過程を経て得られる分類木の例である。「説明変数2のスコアが1であるか」、「説明変数9のスコアが1であるか」、「説明変数3のスコアが2未満であるか」という質問への回答に応じて、建て替え・取り替えの要否を判定する。新た

に入力した点検結果において、該当項目に対する質問への回答がYesならば左、Noならば右に進む。最終的に辿り着いた終端ノード内の数値が1ならば必修が必要、0ならば不要となる。例えば、「説明変数2のスコアが1ではなく」かつ「説明変数3のスコアが2以上」であれば、必修が必要と判定されることになる。

4. 実データを用いた検証

2.2節で示したデータを学習用データと検証用データの二種類に分割し、3.2節で示した決定木学習を適用した。学習用データは過去の記録、検証用データは新たな点検対象に相当する。

機械学習による分類は、目的変数の偏りに左右されやすい¹⁶⁾。そこで、異常サンプル(要建て替えのコンクリート電柱、要取り替えの柱上変圧器)と同数のサンプルを正常サンプル(異常は確認されたが運用可能と判断されたコンクリート電柱、柱上変圧器)から無作為に抽出して使用することとした。つまり、コンクリート電柱では3792本分、柱上変圧器では3510台分のデータを用いることとなる。それらの内、90%を学習用、10%を検証用のデータとして分割した。分割したデータの偏りの影響を緩和するため、交差検証の考え方に従って学習用データと検証用データとを入れ替え、10個ずつ決定木を構築することとした。

4.1 判定精度の評価方法

学習用データを用いて構築した決定木に検証用データを入力し、決定木の判定精度を評価する。判定精度の評価には、(4)~(6)式で定義される正解率(ACC)、適合率(PPV)、再現率(TPR)の三つの指標¹⁷⁾を用いた。TPは真陽性(True Positive)であり、決定木が「必修が必要」と判定した設備の内、DNOも「必修が必要」と判断したものの数で

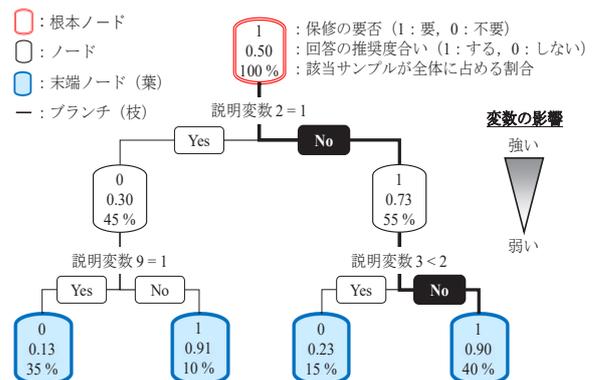


図1 決定木(分類木)の例

ある。FPは偽陽性 (False Positive) であり、決定木が「保修が必要」と判定した設備の内、DNOは「保修は不要」と判断したものの数である。TNは真陰性 (True Negative) であり、決定木が「保修は不要」と判定した設備の内、DNOも「保修は不要」と判断したものの数である。FNは偽陰性 (False Negative) であり、決定木が「保修は不要」と判定した設備の内、DNOは「保修が必要」と判断したものの数である。

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (4)$$

$$PPV = \frac{TP}{TP+FP} \times 100 \quad (5)$$

$$TPR = \frac{TP}{TP+FN} \times 100 \quad (6)$$

(4) 式の正解率 (ACC) は、DNOの判断と決定木の判定結果が完全に一致した割合である。(5)式の適合率 (PPV) は、決定木が「保修が必要」とした設備の内、DNOも「保修が必要」と判断したものの割合を意味する。(6)式の再現率 (TPR) は、DNOが「保修が必要」と判断した設備の内、決定木も「保修が必要」と判定したものの割合を意味する。

4.2 判定精度の評価結果

表5、6はコンクリート電柱、表7、8は柱上変圧器の判定結果である。表5～8より、各指標の値に

大きなバラツキが見られることは無く、概ね安定した結果が得られたことが分かる。また、各指標 (ACC, PPV, TPR) の平均値は、コンクリート電柱ではそれぞれ87.2%, 86.3%, 88.7%, 柱上変圧器ではそれぞれ86.1%, 87.5%, 84.3%となった。正解率が高い場合は他の指標も高くなり、低い場合はその逆となる傾向を示した。

DNOは、通常点検の結果のみを用いて配電設備の保修内容を決定するわけではない。実際、説明変数であるエリア番号、点検結果の値が全て同じで、目的変数である建て替え・取り替え要否のみが異なるものも含まれていた。構築した決定木ではこれらを判別することはできないため、判定精度は確実に低下することになる。また、今回は、コンクリート電柱の建て替え、柱上変圧器の取り替えを判断した際に、大きな影響を与えた点検項目 (エリア番号も含む) を明らかにすることを目指して、決定木学習を採用している。適用した決定木学習は、精度向上戦略などを加えたものではなく、最も基本的なものである。これらより、表5～8で示した結果は、比較的良好な結果であると判断している。なお、ランダムフォレスト¹⁸⁾をはじめ、精度面で優れた結果を示すとされる手法は多数提案されている。著者らも、決定木学習をランダムフォレストに置き換えることで、精度が向上することを確認している⁸⁾。

表5 コンクリート電柱の判定精度

決定木番号	ACC	PPV	TPR
1	89.2	88.9	90.3
2	87.6	87.2	89.4
3	85.8	84.4	88.7
4	87.1	84.1	90.1
5	86.8	88.4	85.7
6	86.0	82.9	91.1
7	88.9	88.1	89.1
8	88.4	88.2	87.2
9	86.8	83.7	90.9
10	85.8	86.8	84.0

表6 コンクリート電柱の結果のまとめ

評価指標	平均値	最良値	最悪値
ACC	87.2	89.2	85.8
PPV	86.3	88.9	82.9
TPR	88.7	91.1	84.0

表7 柱上変圧器の判定精度

決定木番号	ACC	PPV	TPR
1	85.8	82.3	86.5
2	88.3	89.3	87.8
3	86.3	90.4	82.5
4	89.2	88.6	87.5
5	87.7	88.3	86.8
6	84.9	89.2	80.9
7	86.6	89.1	84.8
8	86.0	89.3	83.0
9	80.6	81.7	77.9
10	85.5	86.5	85.1

表8 柱上変圧器の結果のまとめ

評価指標	平均値	最良値	最悪値
ACC	86.1	89.2	80.6
PPV	87.5	90.4	81.7
TPR	84.3	87.5	77.9

以上より、点検・保守記録を学習したAIによって設備保守の要否を自動判定するという考え方は、その有効性が期待できるものと言えよう。

4.3 重要度変数の算出結果

図2, 3は、4.2節で示した全ての決定木について、変数重要度を求めた結果を示している。また、図4, 5は、正解率が最良となった決定木、最悪となった

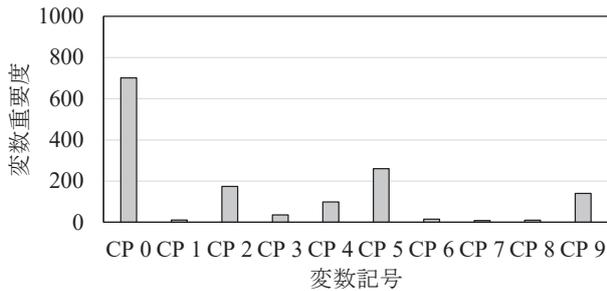


図2 コンクリート電柱の変数重要度 (平均値)

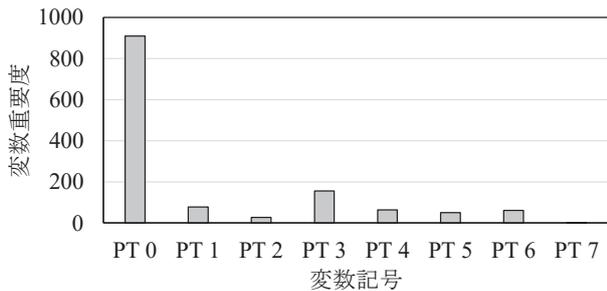
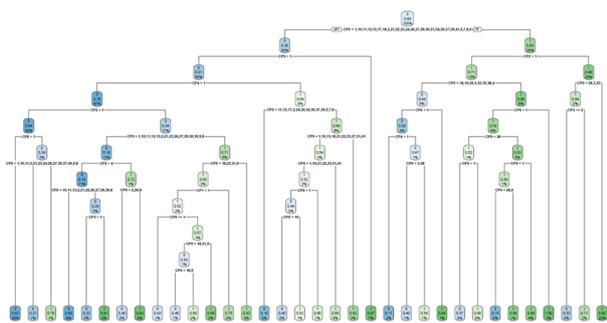


図3 柱上変圧器の変数重要度 (平均値)

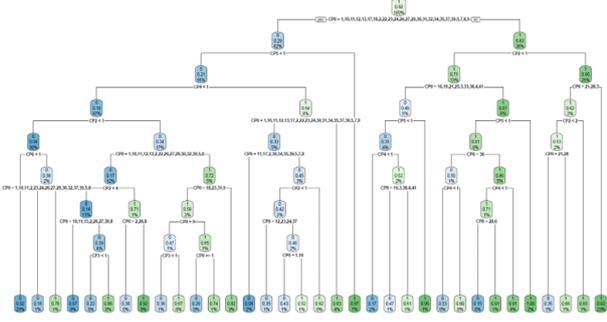
決定木の例である。コンクリート電柱については、決定木3, 10が同値で最悪となったため、再現率でも最悪となった決定木10を示すこととした。なお、柱上変圧器の決定木9は、全指標が最悪となった。

図2, 3に示す通り、それぞれの上位3項目は、コンクリート電柱ではCP 0, CP 5, CP 2, 柱上変圧器ではPT 0, PT 3, PT 1の順となっている。いずれにおいても、エリア番号（コンクリート電柱ではCP 0, 柱上変圧器ではPT 0）が最も大きな影響を持っていたことが分かる。図4, 5を見ても、エリア番号が頻繁に登場している。ただし、エリア番号のみで建て替え・取り替え要否が決まることは少なく、いずれかの点検項目に関する条件分岐を伴っていた。実務上もエリア番号のみで建て替え・取り替えの要否は決まらないこと、得られた決定木で重視されていた点検項目（CP 5, CP 2, PT 3, PT 1）はDNOも重視する項目であったことを確認している。

説明変数の一つとして加えたエリア番号は、設備の立地条件の一部を反映したものと言える。立地条件が異なれば、点検スコアの解釈にも違いを生じる可能性があると考え、説明変数に加えることとした。実際、エリア番号を除外した場合には、精度が低下することも確認している。変数重要度に関する分析は現在も継続中で確かなことは言えないが、これらを詳細に分析することで、設備点検時に留意すべき

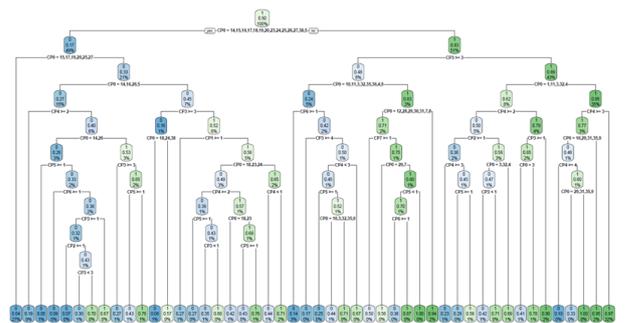


(a) 決定木1 (ACC 最良)

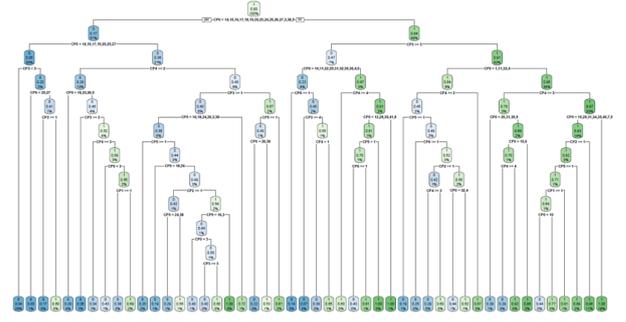


(b) 決定木10 (ACC, TPR 共に最悪)

図4 コンクリート電柱の決定木



(a) 決定木4 (ACC 最良)



(b) 決定木9 (ACC, PPV, TPR の全て最悪)

図5 柱上変圧器の決定木

事項を具体化できるのではないかと著者らは考えている。これが実現すれば、点検・保守記録を学習したAIは、単に保守要否の判断に資するのみでなく、電気保安人材の技術継承にも貢献し得ることになる。

5. まとめ

本稿では、AIを利用して、点検結果から建て替え・取り替え要否を自動的に判定する取り組みを紹介した。現状は基礎検討段階にあるため限定的な情報に決定木学習を適用したに留まるが、今後繋がる比較的良好的な結果が得られたものと著者らは考えている。また、構築した決定木から、電気保安人材の技術継承に役立つ情報が得られる可能性があることにも言及した。

今後は、説明変数や目的変数の見直し、適用する手法の変更により、判定精度の向上を図る予定である。また、得られた結果を詳細に分析し、DNOのノウハウを抽出して技術継承に役立つ形としてまとめる技術についても検討していきたい。

謝辞

本稿で示したデータは、関西電力送配電株式会社より提供頂いたものである。同社からは、本研究に関する様々な情報も提供頂いている。また、本稿を執筆するにあたり、岐阜大学大学院自然科学技術研究科の中山 夏実氏（2024年3月修了）、塚本 恋氏にも多大な支援を頂いた。ここに深く感謝申し上げます。

参考文献

- 1) Department of Defense : "Operation and Maintenance (O&M) Exterior Power Distribution Systems", Unified Facility Criteria UFC 3-550-07, https://www.wbdg.org/FFC/DOD/UFC/ufc_3_550_07_2017.pdf (Accessed July 31, 2024)
- 2) 関西電力送配電株式会社:「第1規制期間(2023~2027年度)における事業計画」, https://www.emsc.meti.go.jp/activity/emsc_electricity/pdf/0014_07_02.pdf (Accessed July 31, 2024)
- 3) スマート官民協議会:「電気保安分野 スマート保安アクションプラン」, https://www.meti.go.jp/shingikai/safety_security/smart_hoan/denryoku_anzen/pdf/20210430_2.pdf (Accessed July 31, 2024)
- 4) 製品評価技術基盤機構:「スマート保安技術カタログ(電気保安)第14版」, https://www.nite.go.jp/gcet/tso/smart_hoan_catalog.pdf (Accessed July 31, 2024)
- 5) エネルギー分野に関わるビッグデータならびにその利用技術調査専門委員会:「エネルギー分野に関わるビッグデータならびにその利用技術」, 電気学会技術報告, Vol. 1441, 2019.
- 6) 高野浩貴, 矢野亨, 進博正, 豊嶋伊知郎:“電力分野のビッグデータと活用事例”, スマートグリッド, 2018年10月号, 大河出版, 2018
- 7) N. Iwase, H. Takano, H. Asano, J. Oasa, S. Higashiyama : “Decision Support Model on Maintenance for Electrical Components in Distribution Network Using Their inspection and Maintenance Records”, Proc. of CIGRE 2022 Kyoto Symposium, C000058, 2022.
- 8) H. Takano, N. Iwase, N. Nakayama, H. Asano, U. Kanenari, Y. Nishihiro : “Decision Support Model for Maintenance of Power Distribution Components Utilizing Inspection and Maintenance Records”, Proc. The 22nd IFAC World Congress, 417-420, 2023.
- 9) 一瀬龍太郎:「【記事更新】 共有知識としてのAI [第1回] AIってなに?」, https://www.ai-gakkai.or.jp/resource/ai_comics/comic_no1/ (Accessed July 31, 2024)
- 10) L. Rokach, O. Maimon : “Data Mining with Decision Trees 2nd ed.”, World Scientific Publishing : Singapore, 1993
- 11) X. Wu, V. Kumar, J. R. Quinlan, J. Ghosh, Q. Yang, H. Motoda, G. J. McLachlan, A. Ng, B. Liu, P. S. Yu, Z. H. Zhou, M. Steinbach, D. J. Hand and D. Steinberg : “Top 10 algorithms in data mining”, Knowl. Inf. Syst., 14 (1), 1-37, 2008
- 12) J. R. Quinlan : “C4.5 : Programs for Machine Learning”, Morgan Kaufmann Publishers : Burlington, MA, USA, 1993.
- 13) 塩田千幸:「データマイニングの手法と実際」, 計算機統計学, 10 (2), 127-144, 1997.
- 14) S. Singh, M. Giri : “Comparative Study Id3, Cart and C4.5 Decision Tree Algorithm : A Survey”, Int. J. Adv. Inf. Sci. Technol., 3 (7), 47-52, 2014.

- 15) L. Breiman, J. H. Friedman, R. A. Olshen., C. J. Stone : "Classification and Regression Trees", Wadsworth & Brooks/Cole Advanced Book & Software : Monterey, CA, USA, 1984.
- 16) 亀井靖高, 松本真佑, 柿元健, 門田暁人, 松本健一 : 「Fault-prone モジュール判別におけるサンプリング法適用の効果」, 情報処理学会論文誌, 48 (8), 2651-2662, 2007
- 17) I. M. D. Diego, A. R. Redondo, R. R. Fernandez, J. Nvarro, J. M. Moguerza : "General Performance Score for Classification Problems", Appl. Intell., 52, 12049-12063, 2021.
- 18) L. Breiman : "Random Forests", Mech. Learn. 45, 5-32, 2021.

著者略歴



高野 浩貴 (タカノ ヒロタカ)

2006年3月福井大学大学院工学研究科博士後期課程システム設計工学専攻修了。岐阜工業高等専門学校電気情報工学科助手, 助教, 講師, 九州大学大学院システム情報科学研究院電気システム工学部門助教, 福井大学学術研究院工学系部門講師を経て, 2018年4月より岐阜大学工学部電気電子・情報工学科准教授。主として, 電力システムの運用・計画の高度化に関する研究に従事。博士(工学)。